

DOI: 10.15514/ISPRAS-2025-37(2)-4



Предсказание характеристик СБИС по логической схеме с помощью методов машинного обучения

^{1,2} М.С. Лебедев, ORCID: 0000-0002-0207-7672 <lebedev@ispras.ru>

¹ Д.А. Дыскина, ORCID: 0009-0008-0298-1822 <dashadysk0804@gmail.com>

¹ А.Ю. Еременко, ORCID: 0009-0008-2358-5191 <eremenko_ay@mail.ru>

¹ Ф.А. Кабанов, ORCID: 0009-0007-6817-4823 <nxizer@gmail.com>

¹ И.А. Козмин, ORCID: 0009-0001-4752-5280 <ilya24624864@gmail.com>

¹ Д.М. Петренко, ORCID: 0009-0001-1067-3490 <petrenko.dan.work@gmail.com>

¹ Н.Б. Поудял, ORCID: 0009-0008-7423-9977 <poudialn@gmail.com>

¹ А.А. Сергеев, ORCID: 0009-0002-3854-7565 <weshaimer13@gmail.com>

¹ Р.А. Ширинова, ORCID: 0009-0002-0265-8458 <renochka7@gmail.com>

¹ Российский Экономический Университет им. Г.В. Плеханова,
Россия, 115054, г. Москва, Стремянный переулок, д. 36.

² Институт системного программирования им. В.П. Иванникова РАН,
Россия, 109004, г. Москва, ул. А. Солженицына, д. 25.

Аннотация. Разработка цифровой аппаратуры – длительный процесс, одними из основных этапов которого являются логический и физический синтез. Несмотря на автоматизацию синтеза в современных САПР, он может занимать часы или даже дни. Применение методов машинного обучения может помочь прогнозировать результаты синтеза и за счет этого ускорить весь процесс разработки. В данной статье описан опыт создания и оценки восьми моделей машинного обучения для прогнозирования площади и задержки СБИС по ее схеме на этапе логического синтеза. Полученные результаты показывают перспективность данного подхода и указывают направления для дальнейших исследований.

Ключевые слова: машинное обучение; искусственный интеллект; системы автоматизации проектирования (САПР); логический синтез; логическая схема; конъюнкторно-инверторные графы (AIG).

Для цитирования: Лебедев М.С., Дыскина Д.А., Еременко А.Ю., Кабанов Ф.А., Козмин И.А., Петренко Д.М., Поудял Н.Б., Сергеев А.А., Ширинова Р.А. Предсказание характеристик СБИС по логической схеме с помощью методов машинного обучения. Труды ИСП РАН, том 37, вып. 2, 2025 г., стр. 49–60. DOI: 10.15514/ISPRAS-2025-37(2)-4.

Благодарности: Исследование выполнено в РЭУ им. Г.В. Плеханова за счет гранта Российского научного фонда № 23-21-00313, <https://rscf.ru/project/23-21-00313>.

Netlist-Based ASIC Area and Delay Prediction Using Machine Learning

^{1,2} M.S. Lebedev, ORCID: 0000-0002-0207-7672 <lebedev@ispras.ru>

¹ D.A. Dyskina, ORCID: 0009-0008-0298-1822 <dashadysk0804@gmail.com>

¹ A.Y. Eremenko, ORCID: 0009-0008-2358-5191 <eremenko_ay@mail.ru>

¹ F.A. Kabanov, ORCID: 0009-0007-6817-4823 <nxizer@gmail.com>

¹ I.A. Kozmin, ORCID: 0009-0001-4752-5280 <ilya24624864@gmail.com>

¹ D.M. Petrenko, ORCID: 0009-0001-1067-3490 <petrenko.dan.work@gmail.com>

¹ N.B. Poudial, ORCID: 0009-0008-7423-9977 <poudialn@gmail.com>

¹ A.A. Sergeev, ORCID: 0009-0002-3854-7565 <weshaimer13@gmail.com>

¹ R.A. Shirinova, ORCID: 0009-0002-0265-8458 <renochka7@gmail.com>

¹ Plekhanov Russian University of Economics,
36, Stremyanny lane, Moscow, 115054, Russia.

² Ivannikov Institute for System Programming of the Russian Academy of Sciences,
25, Alexander Solzhenitsyn st., Moscow, 109004, Russia.

Abstract. Hardware development is a time-consuming process that includes logic synthesis, placement and routing as its main steps. Despite that these steps are automated in modern CADs, their execution can take hours or even days. The application of machine learning methods can help predict synthesis results and thereby speed up the development process. This article describes the experience of creating and evaluating eight machine learning models for predicting area and delay of the synthesized ASIC using its netlist at the logic synthesis step. The results obtained show the benefits of this approach and indicate directions for further research.

Keywords: machine learning; artificial intelligence; EDA; logic synthesis; netlist; AIG.

For citation: Lebedev M.S., Dyskina D.A., Eremenko A.Y., Kabanov F.A., Kozmin I.A., Petrenko D.M., Poudial N.B., Sergeev A.A., Shirinova R.A. Netlist-based ASIC area and delay prediction using machine learning. *Trudy ISP RAN/Proc. ISP RAS*, vol. 37, issue 2, 2025. pp. 49-60 (in Russian). DOI: 10.15514/ISPRAS-2025-37(2)-4.

Acknowledgements. This research was carried out at Plekhanov Russian University of Economics at the expense of a grant from the Russian Science Foundation, № 23-21-00313, <https://rscf.ru/project/23-21-00313>.

1. Введение

Машинное обучение всё чаще применяется в различных областях человеческой деятельности. Не обходит эта тенденция и современные системы автоматизированного проектирования (САПР) микроэлектроники.

Проектирование аппаратуры – многоэтапный и длительный процесс, включающий в себя такие стадии как: разработка спецификации цифрового устройства, создание модели уровня регистровых передач (register transfer level, RTL), логический синтез (создание и оптимизация логической схемы, отображение в технологический базис) и физический синтез (размещение и трассировка элементов на кристалле, генерация топологии). Последние две стадии полностью автоматизированы в современных САПР, однако содержат большое количество настроек и могут занимать длительное время. При этом точные физические характеристики разработанной сверхбольшой интегральной схемы (СБИС) становятся известны только по завершении процесса синтеза.

Основными характеристиками СБИС можно назвать энергопотребление, производительность и площадь на кристалле (power, performance, area, PPA). Разработанная СБИС обычно должна удовлетворять некоторым ограничениям на эти характеристики, либо какая-то из них должна быть максимизирована/минимизирована. Конечные параметры СБИС

трудно спрогнозировать из-за недетерминированности процесса синтеза, наличия множества параметров и настроек и непредсказуемости их влияния на синтезируемую схему. А расчетные значения характеристик до этапов размещения и трассировки могут в разы отличаться от реальных. Поэтому процесс разработки зачастую является итеративным и длительным: нужно многократно проводить синтез, подбирая необходимые параметры. Применение машинного обучения может позволить точнее прогнозировать характеристики СБИС и негативные эффекты (например, перегруженность соединительных линий или падение напряжения в цепях питания) и ускорить процесс разработки за счет исключения бесперспективных запусков инструментов синтеза и возможности быстрого исследования проектных альтернатив. Анализ существующих работ показал, что большинство моделей машинного обучения, применяемых для прогнозирования характеристик СБИС, работает со схемами на этапе физического синтеза, т.к. на нем появляется больше информации о синтезируемой схеме (например, план размещения на кристалле). Однако разработчик аппаратуры заинтересован получать прогнозы о результате синтеза как можно раньше, желательно на этапе RTL-модели или логической схемы.

В данной статье описан опыт применения восьми моделей машинного обучения для прогнозирования производительности и площади СБИС по ее логической схеме до этапа технологического отображения. В качестве набора данных (dataset) для обучения разработанных моделей использовалась часть открытого набора данных OpenABC-D [1]. Раздел 2 посвящен обзору существующих работ по прогнозированию характеристик СБИС. Раздел 3 содержит описание использованных моделей машинного обучения и набора данных. В разделе 4 приведены результаты экспериментов. Наконец, раздел 5 содержит выводы и направления дальнейших исследований.

2. Обзор существующих работ

Сфера применения методов машинного обучения для прогнозирования различных характеристик СБИС активно развивается. Наиболее часто на различных этапах синтеза прогнозируются значения РРА. Распространено также прогнозирование различных эффектов, например, перегрузки коммутационных линий (congestion). В статье [2] для этого применяется графовая сеть внимания (Graph Attention Network, GAT), а также построение тепловых карт, показывающих участки СБИС с наиболее перегруженными коммутационными линиями. Предложенная модель имеет большую точность предсказания по сравнению с аналитическими моделями.

В статьях [3] и [4] методы машинного обучения применяются для прогнозирования временных характеристик СБИС. В работе [3] для этого используется графовая нейронная сеть, а в работе [4] – регрессия Лассо, нейронные сети и случайный лес. Эксперименты в [3] показывают точность прогнозов, сопоставимую с коммерческими инструментами статического временного анализа. Авторы [4] утверждают, что метод случайного леса позволяет достигать результатов, сравнимых с результатами инструмента синтеза, полученными после этапа трассировки. При этом обе статьи показывают намного большую скорость работы методов машинного обучения по сравнению с инструментами синтеза. Стоит заметить, что обе работы используют признаки для прогнозирующих моделей на основе схем после этапа размещения, когда уже известны некоторые геометрические параметры СБИС.

В работе [5] предлагается метод оценки длины соединений и временных характеристик логической схемы до этапа размещения на основе GAT. Авторы предлагают моделировать отдельно задержки на выходах вентилях и задержки межсоединений, а также извлекать топологическую информацию путем разделения графа.

В работе [1] описывается набор логических схем и сценариев их оптимизации для использования в машинном обучении. Он будет рассмотрен подробнее в следующих

разделах. Помимо самого набора данных OpenABC-D, авторы показывают способы его применения на примере нескольких моделей машинного обучения, основанных на графовой и сверточной нейронных сетях. Эти модели нацелены на прогнозирование качества результата синтеза (количество вентилях в схеме, площадь, задержка). На вход графовой нейронной сети поступает логическая схема, а на вход сверточной нейронной сети – сценарий синтеза. Затем результаты работы этих моделей поступают на вход полносвязной нейронной сети, которая выдает прогнозируемое значение одной из характеристик. Проведенные авторами эксперименты показывают высокое качество прогнозов.

В данной работе было решено использовать набор данных OpenABC-D в качестве основы для машинного обучения. Но, в отличие от большинства рассмотренных статей, были выбраны «простые» модели, а не графовые сети, и общие признаки схем.

3. Прогнозирование характеристик СБИС

3.1. Логические схемы

Как уже было упомянуто, процесс разработки цифрового устройства начинается с создания его RTL-модели на языке описания аппаратуры (hardware description language, HDL), например, Verilog или VHDL. Далее следует стадия логического синтеза, во время которой RTL-модель трансформируется в логическую схему в некотором базисе, не привязанном к конкретной технологической библиотеке. Такую схему можно представить в виде графа, вершины которого представляют собой логические функциональные элементы (вентили), а дуги - соединения между ними. Некоторые вершины графа помечены как входные или выходные. Одно из популярных представлений логических схем – конъюнкторно-инверторные графы (And-Inverter Graph, AIG). В узлах этого графа используются только конъюнкторы (вентили “И”), а дуги могут быть помечены операцией “НЕ”. На рис. 1 изображена схема в базисе И-ИЛИ-НЕ и соответствующий ей AIG.




Рис. 1. Логическая схема в базисе И-ИЛИ-НЕ и соответствующий ей AIG.
Fig. 1. A netlist and its corresponding AIG.

Далее логическая схема подвергается технологически независимой оптимизации, обычно с целью уменьшить ее глубину или количество вентилях в ней. Затем она проходит этап технологического отображения и технологически зависимой оптимизации. На этом этапе схема переводится в базис конкретной технологической библиотеки.

Следующей стадией является физический синтез, состоящий из этапов размещения и трассировки. На этапе размещения функциональные элементы схемы располагаются на плоскости проектируемого кристалла. А на этапе трассировки они соединяются проводниками и слоями металлизации. Наконец, генерируется топология СБИС в виде файла GDSII. Этот файл отправляется на фабрику для производства готового изделия.

В данной работе для прогнозирования характеристик СБИС было решено опираться на технологически независимые схемы, а именно, AIG. Во-первых, так как прогнозирование на ранних стадиях синтеза позволяет ускорить процесс разработки аппаратуры. А во-вторых, прогнозирующие модели для таких схем легко переиспользовать для разных технологических библиотек, так как не требуется извлекать разные признаки схемы в зависимости от используемой технологии.

3.2. Набор данных

В качестве набора данных для обучения прогнозирующих моделей была использована часть логических схем из открытого набора данных логических схем OpenABC-D. Этот набор данных основан на 29 RTL-моделях, взятых из различных открытых источников и реализующих несколько классов функциональности, а именно: коммуникационные протоколы, контроллеры шин, алгоритмы шифрования, алгоритмы обработки цифровых сигналов, микропроцессоры. Размер моделей варьируется от нескольких сотен до сотен тысяч логических вентилей. Для каждой RTL-модели авторы набора данных сгенерировали по 1500 случайных сценариев логической оптимизации инструмента ABC [6], каждый из которых состоит из 20 последовательных трансформаций. Схема, полученная на каждом шаге оптимизации, сохранялась в виде AIG в форматах GraphML [7] и bench [8]. После 20-го шага оптимизированная схема проходила технологическое отображение и размечалась предварительными данными о площади и задержке. В качестве целевой технологии авторы набора данных использовали технологию NanGate 45nm.

Набор данных OpenABC-D предназначен для моделей, прогнозирующих результаты логической оптимизации и получающих на вход исходную логическую схему и сценарий ее оптимизации. Целью нашей же работы являлось прогнозирование характеристик СБИС без учёта сценариев оптимизации, поэтому для обучения прогнозирующих моделей из набора данных OpenABC-D были выбраны только логические схемы, полученные после 20-го шага оптимизации (всего 43 500). Их разметка данными о площади и задержке не менялась.

Отобранный набор данных делился на обучающую и тестовую выборки двумя способами: все RTL-модели известны, некоторые RTL-модели неизвестны. В первом случае в обучающую выборку попадало по 1000 схем из каждой RTL-модели и по 500 - в тестовую выборку. Во втором случае обучающая выборка формировалась из всех логических схем 19-и RTL-моделей, а в тестовую выборку попадали оставшиеся схемы из 10 RTL-моделей.

3.3. Модели машинного обучения

Для прогнозирования характеристик СБИС было разработано восемь моделей машинного обучения:

- полносвязная нейронная сеть;
- сверточная нейронная сеть;
- случайный лес;
- градиентный бустинг XGBoost (XG-бустинг);
- градиентный бустинг LightGBM (LG-бустинг);
- линейная регрессия;

- регрессия Лассо;
- метод опорных векторов.

Модели были программно реализованы с помощью библиотек Pytorch [9] (сверточная нейронная сеть), Tensorflow [10] (полносвязная нейронная сеть), SciKit-Learn [11] (случайный лес, линейная регрессия, регрессия Лассо, метод опорных векторов), XGBoost [12], LightGBM [13].

В качестве входа для моделей машинного обучения использовались следующие признаки логических схем:

- количество первичных входов;
- количество первичных выходов;
- количество конъюнкторов;
- количество инверторов;
- количество буферов;
- глубина схемы (наибольший путь) в вентилях.

Было создано по две версии моделей машинного обучения: для прогнозирования значения площади и для прогнозирования значения задержки (кроме сверточной нейронной сети, которая предсказывала сразу оба значения). Каждая из моделей обучалась на двух разбиениях набора данных (с известными и неизвестными RTL-моделями). Значения энергопотребления не прогнозировались из-за отсутствия соответствующей разметки, а также из предположения, что входные признаки недостаточно характеризуют энергопотребление (для этого требуются сведения о переключательной активности элементов схемы). Гиперпараметры обучаемых моделей подбирались с помощью алгоритма поиска по сетке (grid search).

Качество прогнозирующих моделей оценивалось по трем метрикам: коэффициенту детерминации (R^2), среднеквадратической ошибке (mean squared error, MSE) и средней абсолютной процентной ошибке (mean average percentage error, MAPE). Основной метрикой была выбрана MAPE.

4. Эксперименты

Результаты обучения моделей для прогнозирования площади представлены в табл. 1. Наилучший результат на наборе данных со всеми известными RTL-моделями показали модели XG- и LG-бустинга. На наборе данных с неизвестными RTL-моделями лучшей была полносвязная нейронная сеть.

Табл. 2 содержит результаты обучения моделей для прогнозирования задержки. Наилучший результат на наборе данных со всеми известными RTL-моделями опять же показали XG- и LG-бустинги. На наборе данных с неизвестными RTL-моделями на этот раз лучшей был XG-бустинг.

Во время исследования “хорошим” значением MAPE считалось 0.2 (то есть 20%) и меньше. Таким образом, при прогнозировании площади по известным RTL-моделям под этот критерий попали следующие модели: полносвязная нейронная сеть, случайный лес, XG- и LG-бустинги, регрессия Лассо и метод опорных векторов. При прогнозировании площадей по неизвестным RTL-моделям критерию удовлетворяют только полносвязная нейронная сеть и XG-бустинг.

Прогнозирование задержки с необходимой точностью оказалось под силу только XG- и LG-бустингу и только на наборе данных с известными RTL-моделями. На наборе данных с неизвестными RTL-моделями необходимой точности не достигла ни одна модель. При этом

некоторые модели даже показывали неадекватные значения коэффициента детерминации (меньше 0).

Результаты линейной регрессии во всех случаях были наихудшими и выбивающимися из общей картины, что можно объяснить нелинейностью входных данных.

Табл. 1. Результаты прогнозирования значения площади.

Table 1. Area prediction results.

Модель	Набор данных с известными RTL-моделями			Набор данных с неизвестными RTL-моделями		
	R ²	MAPE	MSE	R ²	MAPE	MSE
Полносвязная нейронная сеть	0.995	0.121	8 899 171	0.979	0.100	9 693 661
Свёрточная нейронная сеть	0.454	0.405	138 203 467	0.433	0.420	190 000 000
Случайный лес	0.990	0.037	2 392 959	0.930	0.320	30 025 834
XG-бустинг	0.999	0.012	1 348 663	0.959	0.179	18 729 656
LG-бустинг	0.999	0.016	1 088 640	0.936	0.327	29 187 983
Линейная регрессия	0.932	2.140	2.6*10 ¹⁶	0.050	30.640	3.9*10 ¹⁶
Регрессия Лассо	0.989	0.079	20 417 728	0.979	0.248	9 292 597
Метод опорных векторов	0.987	0.080	24 619 178	0.983	0.440	7 624 740

Табл. 2. Результаты прогнозирования значения задержки.

Table 2. Delay prediction results.

Модель	Набор данных с известными RTL-моделями			Набор данных с неизвестными RTL-моделями		
	R ²	MAPE	MSE	R ²	MAPE	MSE
Полносвязная нейронная сеть	0.565	0.387	159 557 646	-0.026	0.921	257 339 336
Свёрточная нейронная сеть	0.454	0.405	138 203 467	0.433	0.420	190 000 000
Случайный лес	0.510	0.810	179 075 512	1	3.220	503 098 616
XG-бустинг	0.887	0.144	41 527 151	0.427	0.599	143 795 603
LG-бустинг	0.906	0.149	34 277 760	-2.950	3.599	992 478 350
Линейная регрессия	0.935	14.500	2.6*10 ¹⁶	0.050	270.900	3.9*10 ¹⁶

Регрессия Лассо	0.239	0.826	63 702 028	-0.020	0.870	255 980 352
Метод опорных векторов	-0.011	0.730	371 104 033	0.0113	1.240	248 009 158

На рис. 2 изображены диаграммы в координатах площадь/задержка реальных и прогнозных значений характеристик для 29 RTL-моделей. Прогнозирование осуществлялось с помощью модели XG-бустинга на наборе данных с неизвестными RTL-моделями. Можно заметить, что предсказанные значения задержки во многих случаях имеют маленький разброс и располагаются посередине областей реальных значений (то есть, как правило, предсказывается некоторая средняя задержка для данной RTL-модели). Это также может объяснять большие значения среднеквадратической ошибки.

Анализ признаков логических схем показал, что значения площади СБИС сильно коррелируют с количеством вентилях, поэтому прогнозирующие модели показали лучшие результаты именно при предсказании этой характеристики. Некоторая корреляция существует между глубиной схемы и задержкой, но небольшая точность прогнозирующих моделей в этом случае свидетельствует о недостаточной информативности использованных признаков логической схемы.



Рис. 2. Реальные (синие точки) и спрогнозированные моделью XG-бустинга (желтые точки) значения характеристик СБИС.
Fig. 2. Actual (blue dots) and predicted by the XGBoost model (yellow dots) ASIC characteristics.

5. Заключение

В результате проведенной работы были разработаны и обучены восемь моделей машинного обучения, прогнозирующих предварительные значения площади и задержки СБИС по ее логической схеме. Для этого использовалась часть открытого набора данных OpenABC-D. Эксперименты с обученными моделями показали, что требуемое качество прогнозирования достигалось на наборе данных с известными RTL-моделями. Однако при ужесточении требований к качеству, либо при прогнозировании характеристик неизвестных RTL-моделей, разработанные модели машинного обучения показывают неудовлетворительный результат. В связи с этим можно выделить следующие проблемы:

- Малая вариативность набора данных. Несмотря на большое количество схем для обучения, в их основе лежит всего 29 RTL-моделей, а применение большого количества оптимизаций не вносит существенных изменений в эти схемы.
- Недостаточность признаков схем. Входные признаки моделей машинного обучения позволяют прогнозировать на приемлемом уровне только площадь СБИС (коррелирует с количеством вентилях в схеме). Для прогнозирования задержки и энергопотребления имеющиеся признаки явно неинформативны.

Для решения обозначенных проблем требуются дальнейшие исследования. Во-первых, необходимо увеличить количество RTL-моделей в наборе данных, при этом уменьшив количество вариантов их оптимизации. Во-вторых, требуется точная разметка набора данных при помощи САПР физического синтеза, а не предварительная при помощи инструмента ABC. В этом случае при прогнозировании характеристик СБИС потребуются учитывать настройки физического синтеза, которые могут сильно влиять на конечный результат. В-третьих, для прогнозирования задержки и энергопотребления требуются признаки, более полно характеризующие эти аспекты схем (например, переключательная активность элементов).

Так как логические схемы являются графами, одним из направлений для улучшения качества прогнозирования может быть применение графовых нейронных сетей. Этот вид нейронных сетей позволяет учитывать структуру графа помимо его высокоуровневых признаков и часто применяется в машинном обучении в области микроэлектроники.

Список литературы / References

- [1]. Chowdhury A.B., Tan B., Karri R., Garg S. OpenABC-D: A Large-Scale Dataset For Machine Learning Guided Integrated Circuit Synthesis. ArXiv, abs/2110.11292 (online). Доступно по ссылке: <https://arxiv.org/pdf/2110.11292.pdf>, 2021.
- [2]. Kirby R., Godil S., Roy R., Catanzaro B. CongestionNet: Routing congestion prediction using deep graph neural networks. IFIP/IEEE 27th International Conference on Very Large Scale Integration (VLSI-SoC), 2019, pp. 217—222.
- [3]. Guo Z., Liu M., Gu J., Zhang S., Pan D.Z., Lin Y. A timing engine inspired graph neural network model for pre-routing slack prediction. Proceedings of the ACM/IEEE Design Automation Conference (DAC), 2022, pp. 1207—1212.
- [4]. Barboza E. C., Shukla N., Chen Y., Hu J. Machine Learning-Based Pre-Routing Timing Prediction with Reduced Pessimism. ACM/IEEE Design Automation Conference (DAC), 2019, pp. 1-6.
- [5]. Xie Z., Liang R., Xu X., Hu J., Chang C.-C., Pan J., Chen Y. Preplacement Net Length and Timing Estimation by Customized Graph Neural Network. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, vol. 41, No. 11, 2022, pp. 4667-4680.
- [6]. Berkeley Logic Synthesis and Verification Group, ABC: A System for Sequential Synthesis and Verification. Доступно по ссылке: <http://www.eecs.berkeley.edu/~alanmi/abc>, дата обращения: 12.12.2023.
- [7]. Формат файлов GraphML. Доступно по ссылке: <http://graphml.graphdrawing.org>, дата обращения: 12.12.2023.

- [8]. Brglez F., Bryan D., Kozminski K. Combinational profiles of sequential benchmark circuits. 1989 IEEE International Symposium on Circuits and Systems (ISCAS), vol.3, 1989, pp. 1929-1934.
- [9]. Библиотека машинного обучения Pytorch. Доступно по ссылке: <https://pytorch.org>, дата обращения 12.12.2023.
- [10]. Библиотека машинного обучения Tensorflow. Доступно по ссылке: <https://www.tensorflow.org>, дата обращения 12.12.2023.
- [11]. Библиотека машинного обучения SciKit-Learn. Доступно по ссылке: <https://scikit-learn.org>, дата обращения 12.12.2023.
- [12]. Библиотека градиентного бустинга XGBoost. Доступно по ссылке: <https://github.com/dmlc/xgboost>, дата обращения 12.12.2023.
- [13]. Библиотека градиентного бустинга LightGBM. Доступно по ссылке: <https://github.com/microsoft/LightGBM>, дата обращения 12.12.2023.

Информация об авторах / Information about authors

Михаил Сергеевич ЛЕБЕДЕВ является старшим научным сотрудником научной лаборатории «Гетерогенные компьютерные системы» РЭУ им. Г.В. Плеханова, а также научным сотрудником Института Системного Программирования им. В.П. Иванникова РАН. Сфера научных интересов: логический синтез, машинное обучение, нейронные сети, цифровая аппаратура.

Mikhail Sergeyevich LEBEDEV is a senior researcher at the «Heterogeneous computer systems» laboratory of Plekhanov RUE, and a researcher at Ivannikov Institute for System Programming of the RAS. His research interests are: logic synthesis, machine learning, neural networks, digital hardware.

Дарья Алексеевна ДЫСКИНА является студентом направления «Информационная безопасность» в РЭУ им. Г.В. Плеханова. Ее научная деятельность связана с применением методов машинного обучения в процессе оптимизации цифровых схем.

Daria Alexeevna DYSKINA is a student of the «Information Security» program at the Plekhanov Russian University of Economics. Her scientific activities are related to the application of machine learning methods in the process of optimizing digital circuits.

Анастасия Юрьевна ЕРЕМЕНКО является студентом направления «Прикладная математика и информатика» РЭУ им. Г.В. Плеханова. Ее научные интересы включают анализ данных, машинное обучение и искусственный интеллект.

Anastasia Yuryevna EREMENKO is a student of the «Applied Mathematics and Computer science» program at the Plekhanov Russian University of Economics. Her research interests include data analytics, machine learning and artificial intelligence.

Фёдор Александрович КАБАНОВ является студентом направления «Информационная безопасность» в РЭУ им. Г.В. Плеханова. Его научная деятельность связана с применением методов машинного обучения в процессе оптимизации цифровых схем.

Fedor Aleksandrovich KABANOV is a student of the «Information Security» program at Plekhanov Russian University of Economics. His scientific activities are related to the application of machine learning methods in the process of optimizing digital circuits.

Илья Александрович КОЗМИН является студентом направления «Прикладная математика и информатика» в РЭУ им. Г.В. Плеханова. Его научные интересы включают искусственный интеллект, работа с большими данными, методы оптимизации логических схем.

Ilya Aleksandrovich KOZMIN is a student of the «Applied Mathematics and Computer science» program at the Plekhanov Russian University of Economics. His research interests include artificial intelligence, big data, netlist optimization methods.

Даниил Михайлович ПЕТРЕНКО является студентом направления «Информационная безопасность» в РЭУ им. Г.В. Плеханова. Его научные интересы связаны с применением машинного обучения для анализа логических схем цифровых устройств.

Daniil Mikhailovich PETRENKO is a student of the «Information Security» program at the Plekhanov Russian University of Economics. His research interests are related to the application of machine learning to netlist analysis.

Никита Басуевич ПОУДИАЛ является студентом направления «Информационная безопасность» в РЭУ им. Г.В. Плеханова. Его научная деятельность связана с использованием машинного обучения для анализа больших данных.

Nikita Basuevich POUDIAL is a student of the «Information Security» program at Plekhanov Russian University of Economics. His research activity is related to the usage of machine learning to analyze massive data.

Андрей Алексеевич СЕРГЕЕВ является студентом направления «Информационная безопасность» в РЭУ им. Г.В. Плеханова. В сферу его научных интересов входит изучение нейронных сетей и процессов, связанных с их оптимизацией.

Andrey Alekseevich SERGEEV is a student at the «Information Security» program at the Plekhanov Russian University of Economics. His research interests include the study of neural networks and processes related to their optimization.

Рена Афрайл кызы ШИРИНОВА является студентом РЭУ им. Г.В. Плеханова по специальности «Прикладная математика и информатика в экономике». Ее научные интересы включают машинное обучение и обучение с подкреплением.

Rena Afrail kyzy SHIRINOVA is a student of the «Applied Mathematics and Computer science in economics» program at the Plekhanov Russian University of Economics. Her research interests include machine learning, in particular, reinforcement learning.

